

Melhoria da Tolerância ao Ruído na Recuperação de Padrões em Níveis de Cinza da Memória Associativa Morfológica

Ana B. Alvarez, José R. de Oliveira (Orientador)

Departamento de Engenharia de Computação e Automação Industrial (DCA)
Faculdade de Engenharia Elétrica e de Computação (FEEC)
Universidade Estadual de Campinas (Unicamp)
Caixa Postal 6101, CEP 13083-970 – Campinas, SP, Brasil

{anabe, jro}@dca.fee.unicamp.br

Abstract – Morphological associative memories (MAMs) are a special type of associative memory which exhibit optimal absolute storage capacity and one-step convergence. This associative model substitutes the additions and multiplications used by other models by computing maximums and minimums. This type of associative model has been applied to different pattern recognition problems including face localization and voice restoration. Despite of his power, MAMs have been applied in problems that involve gray scale images with some limitations. In this paper, a new improvement approach of the perfect recall rate of gray-scale morphological associative memory (MAM) is presented. A genetic algorithm is used to improve the storage of patterns in memory.

Keywords – Associative memories, Morphological associative memories, Pattern recall, Pattern restoration.

1. Introdução

O conceito de memória associativa (AM do termo em inglês *Associative Memory*) emerge das teorias psicológicas de aprendizagem humana e animal. Estas memórias armazenam informação por correlação de aprendizagem entre os diferentes estímulos. Quando um estímulo é apresentado como uma sugestão de memória, outro é recuperado em consequência. Isso significa que os dois tornaram-se estímulos associados uns aos outros na memória.

Uma AM pode ser vista como um tipo particular de rede neural projetada para recuperar itens da memória a partir de informações parciais, isto é, recordar padrões a partir de entradas que possam aparecer alteradas por alguma classe de ruído. Alguns modelos associativos têm sido descritos nos últimos anos (referem-se, por exemplo [1,7,8,11,13,14]). A maioria de estas AMs tem algum tipo de restrição que limita sua aplicabilidade em problemas complexos. Dentro destas restrições se podem mencionar a capacidade de armazenamento (limitado), o tipo de padrões (só binário, bipolar, inteiro ou padrões reais) e a exclusiva robustez ao ruído (apenas aditivo, subtrativo, misto, Gaussiano, etc.).

Um primeiro esforço em formular redes neurais morfológicas uteis foi proposto por Davidson et al. [2]. Desde então são poucos os trabalhos envolvendo redes neurais morfológicas que tem aparecido. Refere-se, por exemplo, a [12]. Em 1998, Ritter et al. [11] propõe o

conceito de memória associativa morfológica (MAM do termo em inglês *Morphological Associative Memory*) e o conceito de memória auto-associativa morfológica (MAAM do termo em inglês *Morphological Auto-associative Memory*). Basicamente, os autores substituem o produto exterior por operações de **max** e **min**. As propriedades das MAMs comparadas com o modelo associativo de Hopfield se diferenciam em vários aspectos, sendo as mais importantes a sua ótima capacidade de armazenamento absoluto e a convergência em um passo só no caso auto-associativo. Porém, esta versão de memórias ao serem aplicadas ao problema de recuperação de imagens possuem uma robustez ao ruído seletiva para específicos tipos de ruído (subtrativo e aditivo) dificultando a sua aplicação diretamente em problemas reais. Para resolver as deficiências deste modelo, alguns trabalhos têm sido desenvolvidos e aplicados à recuperação e reconhecimento de imagens em níveis de cinza [3,5,10,13].

Os algoritmos genéticos (GA do termo em inglês *Genetic Algorithms*) foram propostos por Holland [6] e podem ser vistos como um método de busca baseado em mecanismos de seleção baseados na genética biológica e difere dos métodos de otimização tradicional em alguns aspectos [4]. Dentro das principais qualidades podemos mencionar seu mecanismo de busca inerentemente paralelo atuando em um conjunto de soluções em potencial, e a utilização de informação objetiva e não derivativa ou conhecimentos auxiliares na tentativa de encontrar uma solução ótima global.

Neste artigo é descrita a combinação de uma MAAM com um GA para ser aplicado em problemas envolvendo imagens em níveis de cinza. Um completo estudo de funcionamento de esta abordagem na recuperação de imagens em níveis de cinza é realizado e é demonstrado que otimizando a construção da memória da MAAM um desempenho melhor na recuperação de imagens é alcançado.

2. Proposta

A estrutura matemática dos algoritmos genéticos foi estabelecida por Holland e pode ser descrito como um método de busca estocástico que imita a regra de avaliação biológica natural e é considerada uma ferramenta eficiente na busca do ótimo global. A combinação de memórias auto-associativas morfológicas e algoritmos genéticos utiliza esta vantagem para lidar com a construção da memória auto-associativa morfológica.

As memórias associativas morfológicas propostas por Ritter et al. tem sua base na estrutura da álgebra de Lattice $(\mathbb{R}, \wedge, \vee, +)$ onde os símbolos \wedge e \vee denotam os produtos mínimo e máximo, respectivamente.

Seja $\mathbf{x} \in \mathbb{R}^n$ um padrão de entrada e $\mathbf{y} \in \mathbb{R}^m$ um padrão de saída. Uma associação entre os padrões \mathbf{x} e \mathbf{y} é denotada como $(\mathbf{x}^\xi, \mathbf{y}^\xi)$, onde ξ é a associação correspondente.

Uma versão corrompida de um padrão \mathbf{x} a ser recuperado pode ser definida como $\tilde{\mathbf{x}}^\xi$. Se a memória associativa for alimentada com $\tilde{\mathbf{x}}^\xi$, e o padrão de saída \mathbf{y}^ξ é exatamente recuperado, se diz que a recuperação é perfeita e robusta.

Suponha que seja dado um par de vetores padrões $\mathbf{x} = (x_1, x_2, \dots, x_n)^t \in \mathbb{R}^n$ e $\mathbf{y} = (y_1, y_2, \dots, y_m)^t \in \mathbb{R}^m$. Uma memória associativa morfológica que permite a recuperação do vetor padrão \mathbf{y} a partir de um vetor entrada \mathbf{x} é definida através da equação:

$$\mathbf{W} = \mathbf{y} \wedge (-\mathbf{x})^t = \begin{pmatrix} y_1 - x_1 & \dots & y_1 - x_n \\ \vdots & \ddots & \vdots \\ y_m - x_1 & \dots & y_m - x_n \end{pmatrix} \quad (1)$$

desde que \mathbf{W} satisfaça a relação do mapeamento associativo descrito pela equação:

$$\mathbf{y} = \mathbf{W} \vee \mathbf{x} = \begin{pmatrix} \vee_{i=1}^n (y_1 - x_i + x_i) \\ \vdots \\ \vee_{i=1}^n (y_m - x_i + x_i) \end{pmatrix} \quad (2)$$

Para um dado conjunto de associações de padrões $\{(\mathbf{x}^\xi, \mathbf{y}^\xi): \xi = 1, \dots, k\}$ são definidos um

par de matrizes padrão (\mathbf{X}, \mathbf{Y}) , onde $\mathbf{X} = (\mathbf{x}^1, \dots, \mathbf{x}^k)$ e $\mathbf{Y} = (\mathbf{y}^1, \dots, \mathbf{y}^k)$. Para cada par de matrizes (\mathbf{X}, \mathbf{Y}) , são associadas duas memórias morfológicas $\mathbf{W}_{\mathbf{XY}}$ e $\mathbf{M}_{\mathbf{XY}}$ definidas pelas equações:

$$\mathbf{W}_{\mathbf{XY}} = \mathbf{Y} \wedge \mathbf{X}^* = \bigwedge_{\xi=1}^k [\mathbf{y}^\xi \wedge (-\mathbf{x}^\xi)^t] \quad (3)$$

$$\mathbf{M}_{\mathbf{XY}} = \mathbf{Y} \vee \mathbf{X}^* = \bigvee_{\xi=1}^k [\mathbf{y}^\xi \vee (-\mathbf{x}^\xi)^t] \quad (4)$$

Se $\mathbf{X} = \mathbf{Y}$, ou seja, $\mathbf{x}^\xi = \mathbf{y}^\xi$ para $\xi = 1, \dots, k$ se obtêm as MAAM $\mathbf{W}_{\mathbf{XX}}$ e $\mathbf{M}_{\mathbf{XX}}$. Que serão de interesse neste artigo.

Um conjunto completo de teoremas que garantem que as MAAM têm capacidade de armazenamento ilimitada e provêm recuperação perfeita do padrão e suas correspondentes provas são encontradas em [9,11].

\mathbf{W} e \mathbf{M} possuem uma robustez ao ruído seletiva para específicos tipos de ruído. Enquanto a memória \mathbf{W} apresenta maior robustez na presença de ruído subtrativo, a memória \mathbf{M} terá uma robustez maior para ruído aditivo. Características que limitam sua aplicação direta em problemas reais. No modelo proposto, as matrizes \mathbf{W} e \mathbf{M} são utilizadas para a construção da memória do modelo proposto.

2.1 Algoritmos genéticos nas MAAMs

Detalhes específicos das operações são as seguintes:

- Inicialização da população: Formada por indivíduos gerados a partir das matrizes \mathbf{W} e \mathbf{M} que são as matrizes $n \times n$ dos pesos calculados pelo método de aprendizagem da MAAM e a população inicial é gerada perturbando aleatoriamente os cromossomos de entrada. O tamanho da população N_p é mantida constante em 300 durante a otimização.
- Função *fitness*: Aplicada da seguinte forma: $F(x_i) = \frac{f(x_i)}{\sum_{i=1}^{N_p} f(x_i)}$ onde N_p é o tamanho da população e x_i é o valor do fenótipo do indivíduo i .
- Operador de recombinação: Nos dois melhores cromossomos uma posição T de coluna é aleatoriamente selecionada entre 1 e $n - 1$, então duas novas matrizes genes são construídas trocando os elementos que se encontram entre a posição $T + 1$ e n .

- d. Operador de mutação: Somente aplicado à matriz gene que tem o valor *fitness* mais alto. Números de colunas ou filas são escolhidos aleatoriamente e perturbações são aplicadas com baixa probabilidade (0,01).

Este procedimento seqüencial é aplicado até que o número máximo de operações seja atingido. Nesta aplicação se considera sendo 1000.

Por praticidade, a memória gerada utilizando algoritmos genéticos será especificada como MAAM-GA (do termo em inglês *Morphological Auto-associative Memory and Genetic Algorithms*).

3. Resultados

Nesta seção é apresentado um estudo do desempenho do modelo MAAM-GA quando é utilizado para resolver o problema de recuperação de padrões em níveis de cinza.

Durante os experimentos realizados são utilizadas imagens de tamanho 64 x 64 com 256 níveis de cinza. As imagens são convertidas em padrões e para cada imagem é gerado um vetor \mathbf{x}^ξ de 4096 de comprimento e cada matriz gene gerada tem 4096x4096 de tamanho. Na figura 1 se apresentam as imagens utilizadas



Figura 1. Padrões fundamentais utilizados para construção da memória MAAM-GA.

Os padrões fundamentais mostrados na figura 1 serão utilizados para a formação da MAAM-GA. Também foram geradas outras memórias como a MAM [8] e a Gray-scale MAM [9] para realizar algumas comparações no processo de recuperação. As memórias obtidas utilizando o modelo MAM são denotadas como \mathbf{W} e \mathbf{M} e as do modelo Gray-scale MAM como $\mathbf{W} + v$ e $\mathbf{M} + u$.

Para medir a diferença entre o padrão fundamental e o padrão recuperado será usado o erro quadrático médio normalizado (EQMN dado por $\frac{\|\mathbf{y}^\xi - \mathbf{M}_{\mathbf{x}\mathbf{y}} \Delta \mathbf{x}^\xi\|}{\|\mathbf{y}^\xi\|}$). A fim de obter valores mais

confiáveis do desempenho repetimos cada experimento 100 vezes para cada modelo.

3.1 MAAM-GA: Capacidade de armazenamento

Considerem-se os padrões fundamentais $\mathbf{x}^1, \mathbf{x}^2, \mathbf{x}^3$ mostrados na figura 1. Uma vez gerada a memória da MAAM-GA os mesmos padrões fundamentais são apresentados como entrada à memória e na saída são encontradas todas as memórias fundamentais. A porcentagem média de pixels corretamente recuperados dos padrões recordados é de 97,7% e o EQMN obtido neste experimento é de $2,7 \times 10^{-6}$.

3.2 MAAM-GA: Desempenho sob padrões em níveis de cinza corrompidos com ruído subtrativo e dilatativo

Considere os padrões corrompidos $\tilde{\mathbf{x}}^1$ e $\tilde{\mathbf{x}}^2$ gerados a partir dos padrões \mathbf{x}^1 e \mathbf{x}^2 introduzindo ruído subtrativo e aditivo a cada padrão respectivamente. A MAAM-GA e a MAM alcançam a recuperação dos padrões fundamentais em uma só iteração. Os valores de EQMN são listados nas tabelas I e II e indicam uma boa tolerância do modelo ao ruído subtrativo e aditivo, respectivamente.

Tabela I. EQMNs produzidos pela MAAM-GA e a MAM \mathbf{W} na apresentação de padrões corrompidos $\tilde{\mathbf{x}}^1$ com ruído subtrativo

	MAAM – GA	\mathbf{W}
10%	1.311699e-003	2.700284e-006
20%	5.047965e-003	4.140910e-006
35%	1.621205e-002	7.493737e-006
50%	3.262694e-002	3.770147e-005

Tabela II. EQMNs produzidos pela MAAM-GA e a MAM \mathbf{M} na apresentação de padrões corrompidos $\tilde{\mathbf{x}}^2$ com ruído aditivo

	MAAM – GA	\mathbf{M}
10%	7.493925e-003	1.376049e-005
20%	2.977242e-002	2.137638e-005
35%	6.786651e-002	6.335545e-005
50%	1.827562e-001	9.657942e-005

3.3 MAAM-GA: Desempenho sob padrões em níveis de cinza corrompidos com ruído aleatório uniformemente distribuído

Utiliza-se o padrão fundamental \mathbf{x}^3 apresentado na figura 1, versões corrompidas $\tilde{\mathbf{x}}^3$ são geradas introduzindo ruído aleatório uniformemente distribuído com média 0 e variância 0.01, 0.03, 0.12, ou 0.25. Ao serem apresentados estes padrões corrompidos como entrada à memória se verifica que uma recuperação quase perfeita é alcançada quando usamos a MAAM-GA. A tabela III mostra os resultados EQMNs obtidos na recuperação do padrão fundamental pelos modelos associativos.

Tabela III. EQMNs produzidos por modelos associativos na apresentação de padrões corrompidos com ruído aleatório uniformemente distribuído com média zero

	MAAM-GA	$\mathbf{M} + u$	$\mathbf{W} + v$
$\sigma^2 = 0.01$	3.392446e-005	6.270816e-002	6.613168e-002
$\sigma^2 = 0.03$	3.574289e-005	5.477505e-002	2.635757e-001
$\sigma^2 = 0.12$	7.329546e-005	3.954329e-001	7.178426e-001
$\sigma^2 = 0.25$	3.101499e-003	3.072105e-001	1.844739e+000

4. Conclusões e Trabalhos Futuros

Este artigo descreve um simples, mas efetivo modelo para a recuperação de imagens em níveis de cinza. O MAAM-GA é uma combinação da memória auto-associativa morfológica e um algoritmo genético que é utilizado na otimização da construção da memória. A combinação das técnicas visa aperfeiçoar o processo de construção da memória para conseguir um desempenho melhor na recuperação de imagens em níveis de cinza.

A tolerância ao ruído do modelo proposto foi comparada com alguns dos mais relevantes modelos associativos morfológicos para imagens em níveis de cinza e que possuem comprovada eficiência na recuperação de padrões corrompidos para o tipo de ruído.

Observa-se nas tabelas I, II, III que o modelo proposto mostrou ter uma boa tolerância na presença dos diferentes tipos de ruído. Característica que somada ao baixo custo computacional na recuperação dos padrões (devido ao processo de recuperação ser realizado em uma única iteração) viabilizará uma conveniente implementação em hardware.

A proposta também pode ser estendida ao caso de imagens *true-color* construindo uma memória para cada canal de cor e em seguida

combinando a informação recuperada por cada memória para finalmente recuperar a imagem *true-color*.

Referências

- [1] J.A. Anderson, A simple neural network generating an interactive memory, *Math. Biosci.*, vol. 14, 1972, pp. 197–220.
- [2] J.L. Davidson, G.X. Ritter, A theory of morphological neural networks, in: *Digital Optical Computing, Proc. SPIE*, vol. 1215, 1990, pp. 378–388.
- [3] N. Feng, Y. Qiu, F. Wang, Y. Sun, A unified framework of morphological associative memories, *Lecture Notes in Control and Information Sciences*, vol. 344, 2006, pp. 1–11.
- [4] D. Goldberg, *Genetic Algorithms in Search, Optimization, and Machine Learning*. Addison-Wesley, 1989.
- [5] M. Graña, J. Gallego, F.J. Torrealdea, A. D’Anjou, On the application of associative morphological memories to hyperspectral image analysis, *Lecture Notes in Computer Sciences*, vol. 2687, 2003, pp. 567–574.
- [6] J. Holland, Outline for a logical theory of adaptive systems, *Journal of the ACM*, 1962, vol. 9(3), pp. 297–314.
- [7] J.J. Hopfield, Neural networks and physical systems with emergent collective computational abilities, *Proc. Natl. Acad. Sci.*, vol. 79, 1982, pp. 2554–2558.
- [8] T. Kohonen, Correlation matrix memories, *IEEE Trans. Comput.*, vol. 21, 1972, pp. 353–359.
- [9] M. Mesquita, Um Estudo Comparativo em Memórias Associativas com Ênfase em Memórias Associativas Morfológicas. Dissertação de Mestrado, IMECC-UNICAMP, Brasil, 2005.
- [10] B. Raducanu, M. Graña, X.F. Albizuri, Morphological scale spaces and associative morphological memories: results on robustness and practical applications, *J. Math. Imaging Vision*, vol. 19 (2), 2003, pp. 113–131.
- [11] G.X. Ritter, P. Sussner, J.L. Diaz de Leon, Morphological associative memories, *IEEE Trans. Neural Networks*, vol. 9, 1998, pp. 281–293.
- [12] C.P. Suarez-Araujo, Novel neural network models for computing homothetic in variances: an image algebra notation, *J. Math. Imaging Vision*, vol. 7(1), 1997, pp. 69–83.
- [13] P. Sussner, M. Valle, Gray-scale morphological associative memories, *IEEE Trans. Neural Networks*, vol. 17, 2006, pp. 559–570.
- [14] R.A. Vazquez, H. Sossa, A new associative memory with dynamical synapses, *Neural Process. Lett.*, vol. 28 (3), 2008, pp. 189–207.